

УДК 681.515: 519.7

Г.В. Кузнецов, В.І. Корнієнко,  
О.В. Герасіна

## КОМПОЗИЦІЙНА СТРУКТУРНО-ПАРАМЕТРИЧНА ІДЕНТИФІКАЦІЯ НЕЛІНІЙНИХ ДИНАМІЧНИХ ОБ'ЄКТІВ КЕРУВАННЯ

### Вступ

Складні динамічні об'єкти керування (ОК) мають нестационарні параметри, нелінійні залежності і стохастичні змінні, що зумовлює наявність у них різних динамічних режимів функціонування. До таких ОК належать, наприклад, технологічні процеси рудопідготовки (дроблення і здрібнювання), витрати на які становлять більше половини собівартості збагачувального виробництва. Створення ефективних систем керування такими ОК передбачає їх ідентифікацію як на стадії проектування, так і в процесі функціонування системи.

Структурно-параметрична ідентифікація вміщає в себе операції визначення структури, оцінки і оптимізації параметрів моделі ОК [1–4]. При цьому актуальними проблемами є вибір базисних функцій, в термінах яких здійснюється ідентифікація, вибір способу генерування і селекції структур різної складності, а також вибір методу параметричної оптимізації і ефективних критеріїв селекції та оптимізації.

Традиційно для апроксимації функцій використовуються поліноми Лежандра чи Колмогорова–Габора, як, наприклад, у методі групового урахування аргументів (МГУА) [1, 2], алгоритмами якого реалізовується схема масової селекції. Але значною проблемою застосування МГУА є правильне співвідношення складності моделі з об'ємом навчальної вибірки.

Зараз для апроксимації функцій більш продуктивним вважається використання нейронних мереж або гібридних нейронних мереж із нечіткою логікою, що є універсальними та ефективними апроксиматорами [5]. Тоді структурно-параметрична ідентифікація полягає [6] у використанні множини предикторів (нейронних мереж із різними структурами і параметрами) в метамережі, вихідний шар якої формується як лінійна комбінація кращих (за величиною похибки) мереж. Але такий підхід має недолік: надмірна складність структури моделі і

отримувані оптимальні рішення є локальними, а не глобальними.

Для вирішення таких проблем у статті [7] запропоновано гібридні еволюційні схеми оптимізації, які засновані на композиційному використанні глобальних і локальних методів. Перевага такого підходу полягає в паралельній роботі методів оптимізації, що істотно знижує час пошуку рішень.

Синтезована модель складного ОК, яка правильно передає динаміку одного режиму функціонування, може бути неадекватною до опису іншого режиму. Тому необхідна реалізація адаптивної ідентифікації ОК у процесі функціонування системи керування, що відносно просто виконується за допомогою нейронних і гібридних мереж, але вона є трудомісткою при традиційному підході.

Таким чином, нерозв'язаною задачею є розробка маловитратних і ефективних методів структурно-параметричної ідентифікації нелінійних динамічних ОК, що мають змінні режими функціонування.

### Постановка задачі

Мета статті – розробка методики структурно-параметричної ідентифікації нелінійних динамічних ОК у класі прогнозуючих нейромережних моделей на базі композиції методів глобальної і локальної оптимізації, а також оцінка ефективності застосування цієї методики на прикладі ідентифікації технологічних процесів рудопідготовки.

### Структурно-параметрична ідентифікація

Сформулюємо задачу ідентифікації ОК таким чином: на підставі експериментальної множини функцій (часових рядів) збурень, керувань і виходів в умовах завад слід визначити структуру (узагальнену функцію  $\Phi$ ) і вектор параметрів  $a$  моделі вигляду [4]

$$\hat{Y}[k+n] = \Phi\{Y[k], u[k], w[k], \xi[k], a[k], k\}, \quad (1)$$

що достатньо точно (згідно з деяким критерієм) апроксимують ОК відносно вхідних і вихідних величин у всьому функціональному просторі. Тут  $Y[k], u[k], w[k], \xi[k]$  – відповідно вектори (матриці) виходу процесу, його керувань, збурень і завад до поточного часу  $k$  з відповідними глибинами пам'яті;  $n$  – глибина прог-

нозу (для компенсації чистого запізнювання і часу на синтез і реалізацію керування).

Вважаємо, що оцінка  $\hat{Z}[k]$  стану ОК (1) виконується за допомогою відповідних фільтрів, тобто

$$\{Y[k], u[k], w[k]\} \subset \hat{Z}[k]. \quad (2)$$

Як міра точності ідентифікації використовується [3], наприклад, критерій мінімуму похибки між експериментальними  $Y^*[k+n]$  і модельними значеннями виходу (1):

$$J = E\{|Y^*[k+n] - \hat{Y}[k+n]|\} \rightarrow \min \quad (3)$$

при дотриманні обмежень на функціональний простір. Тут  $E$  — математичне сподівання.

Отже, формування вектора  $I_s = \{\Phi, a\}$  оцінки структури  $\Phi$  (структурна ідентифікація) і параметрів  $a$  (параметрична ідентифікація) моделі ОК (1) здійснюється на основі векторів сигналів спостереження  $\hat{Z}[k]$  (2) мінімізацією прийнятого функціонала:

$$J[I_s] \rightarrow \min_{I_s \in S} J \Rightarrow I_s^{\text{opt}} = \{\Phi_{\text{opt}}, a_{\text{opt}}\}, \quad (4)$$

де обмеження  $S$ , в загальному випадку, обчислюється за формулою

$$S = \begin{cases} \{h(I_s) \geq 0\} \subseteq S_h, \\ \{g(I_s) = 0\} \subseteq S_g, \\ \{\phi_i, i = \overline{1, D}\} \subseteq S_D. \end{cases} \quad (5)$$

Тут  $h, g$  — неперервні функції;  $\phi_i$  — елементи дискретного вектора  $D$  можливих значень структурної функції  $\Phi = \{\phi_i\}$ .

Вирази (4), (5) є комбінацією неперервної задачі математичного програмування і задачі дискретного програмування. Остання з них при малих  $D$  може розв'язуватися повним перебором, а при великих  $D$  — або структурними методами, або зведенням дискретної задачі до неперервної і подальшим її розв'язанням методами параметричного пошуку.

### Розв'язання задачі ідентифікації

При розв'язанні задачі (4), (5) мають бути визначені (вибрані) ефективні методи оптимізації, зміст критерію (функціонала)  $J$ , способи

обліку обмежень  $S$  та тип структури моделі і базисні функції.

Задача (4), (5), у зв'язку з нелінійністю ОК і довільним виглядом функціонала, є полімодальною, що потребує використання методів глобальної оптимізації, серед яких найбільш ефективними є пошукові методи [3, 8, 9]. В них алгоритм пошуку оптимального розв'язання зв'язує розв'язки, що йдуть один за одним,  $I_s(K+1) = F[I_s(K)]$ , де  $F$  — алгоритм пошуку, що вказує, які операції слід зробити на кроці  $K$  при  $I_s(K)$ , щоб отримати розв'язок  $I_s(K+1) \succ I_s(K)$ . Тут знак переваги  $\succ$  при мінімізації функціонала вживається в такому розумінні:

$$J[I_s(K+1)] < J[I_s(K)]. \quad (6)$$

Алгоритм розв'язання задачі оптимізації  $F$  виконує функції збору інформації і прийняття рішення. Наприклад, в алгоритмах прямого випадкового пошуку (ПВП) [3] задаються напрямки пошуку і визначаються значення функціонала  $J$  в точках  $I_s(K) \pm \gamma\sigma$ . Розв'язання полягає у виборі кроку в напрямку зменшення цього функціонала:

$$I_s(K+1) = I_s(K) - \omega\sigma\{J[I_s(K) + \gamma\sigma] - J[I_s(K) - \gamma\sigma]\}, \quad (7)$$

де  $\omega, \sigma, \gamma$  — параметри, які визначають сфери прийняття рішення ( $\omega$ ), збору інформації ( $\gamma$ ) та одиничний випадковий напрямок ( $\sigma$ ). В загальному випадку ці параметри можуть змінюватися (адаптуватися) до процедури пошуку і виду гіперповерхні прийнятого функціонала.

Розвитком методів випадкового пошуку, насамперед у підвищенні ефективності процедур спрямованого пошуку, є еволюційні алгоритми, що реалізують біологічний підхід для пошуку оптимальних рішень. Найбільше поширення серед них одержали генетичні алгоритми (ГА) [9], основані на моделюванні розвитку біологічної популяції на рівні геномів. Вони моделюють процес біологічної еволюції: мутації структури і параметрів  $\delta I_s$ , їх схрещування (розмноження)

$$I_s(K+1) = I_s(K) + \delta I_s(K) \quad (8)$$

і правило добору. Це дає можливість виявляти їх сприятливі варіації, за допомогою яких буду-

ється послідовність поліпшуваних рішень із властивістю (6).

При розв'язанні задачі (4), (5) актуальним є також вибір критеріїв якості моделі (функціонала  $J$ ). Для структурної ідентифікації ефективними вважаються зовнішні критерії [10], які адекватні задачі побудови моделей із мінімальною дисперсією похибки прогнозу і поділяються на критерії регулярності і критерії незміщеності (мінімуму зсуву) [1].

До критеріїв регулярності належать критерій мінімуму відносної похибки покрокового інтегрування:

$$J_{\varepsilon} = \frac{\|Y^*[k+n] - \hat{Y}[k+n]\|}{\|Y^*[k+n]\|}, \quad (9)$$

який обчислюється на всій вибірці експериментальних даних  $N$ , а також критерій мінімуму вибіркової відносної похибки:

$$J_{\varepsilon B} = \frac{\|Y^*[k+n] - \hat{Y}_A[k+n]\|_B}{\|Y^*[k+n]\|_B}. \quad (10)$$

Тут оптимізація моделі здійснюється на навчальній вибірці  $A$  (вихід моделі  $\hat{Y}_A[k+n]$ ), а перевірка її ефективності (величини похибки) на перевіірочній послідовності  $B$ , що помічено в (10) індексом знизу. Вся вибірка:  $N = A + B$ .

Критерії (9), (10) чутливі до рівня шуму в початкових даних і при збільшенні завад їх мінімум зміщується в область простіших моделей. Більш стійкі до завад критерії незміщеності. Наприклад, критерій мінімуму зсуву, заснований на аналізі розв'язків, має вигляд

$$J_{\text{см}} = \frac{\|\hat{Y}_A[k+n] - \hat{Y}_B[k+n]\|}{\|Y^*[k+n]\|}, \quad (11)$$

де  $\hat{Y}_A[k+n]$  і  $\hat{Y}_B[k+n]$  – виходи моделей, навчених на вибірках  $A$  і  $B$ , відповідно. Тут обчислення зсуву здійснюється на всій вибірці  $N$ .

Для узгодження вимог критеріїв (9)–(11) використовується комбінований критерій, наприклад у вигляді

$$J_{\text{комб}} = \mu J_{\varepsilon} + (1 - \mu) J_{\text{см}}, \quad 0 \leq \mu \leq 1. \quad (12)$$

Обмеження  $I_s(K) + \delta I_s(K) \in S$ , що накладаються при розв'язанні задачі (4), (5), припускають такими:  $\Phi + \delta \Phi \in S$  і  $a + \delta a \in S$ . Обмеження  $S_1 = S_h \cap S_g$  формують неперервну за-

дачу математичного програмування, а  $S_2 = S_h \cap S_D$  – задачу дискретного програмування. При цьому обмеження  $S = \{S_1, S_2\}$  можна врахувати таким чином:

- при обмеженнях типу нерівності  $S \neq S_h$  вдалим вважається крок, коли виконується умова (6) і  $I_s(K) \in S$ , інакше – крок буде невдалий і треба повернутися в попередній стан з подальшим новим кроком із нього;

- при обмеженнях типу рівності  $S = S_g$  вводиться коридор  $\|g(I_s)\| < \varepsilon_{\text{доп}}$ , обмежений допустимою похибкою  $\varepsilon_{\text{доп}}$ ;

- обмеження  $S = S_h \cap S_g$  є комбінацією перших двох випадків;

- при обмеженнях на дискретність структурних функцій  $S = S_D$  здійснюється випадковий вибір нової точки біля початкової точки:  $\|I_{si}(K+1) - I_{si}(K)\| < \varepsilon$ , де  $I_{si}$  – вектор структурно-параметричних факторів із значенням структурної функції  $\phi_i$ . Якщо  $\Theta_{\varepsilon}(K)$  – множина векторів  $I_{si}$ , що задовольняє наведену вище умову, то на  $K+1$ -му кроці з  $\Theta_{\varepsilon}(K)$  вибирають точку (значення  $I_{si}$ ), яке задовольняє умови  $J[I_{si}(K+1)] < J[I_{si}(K)]$  і  $I_{sz}(K+1) \in \Theta_{\varepsilon}(K)$ . Очевидно, що при  $S = S_h \cap S_D$  додатково потрібно, щоб  $I_{si}(K+1) \in S_h$ .

При побудові і реалізації структури динамічної прогнозуючої моделі ОК (1) використовуються різні підходи [3, 11, 12]. При цьому нелінійна динамічна система (модель ОК) може бути подана за допомогою композиції лінійної динамічної (ЛДЛ) і нелінійної статичної (НСЛ) ланок, наприклад, у вигляді моделі Вінера–Гаммерштайна, наведеної на рис. 1.

На рис. 1 ЛДЛ є лініями затримки, величини яких (глибина пам'яті) визначаються розмірністю вхідних  $d_i - 1$  і вихідних  $d_{\bar{y}}$  змінних [13]. А як НСЛ можуть використовуватися як традиційні засоби – поліноми Лежандра чи Колмогорова–Габора, так й інтелектуальні – нейронні мережі (НМ), гібридні НМ з нечіткою логікою тощо.

Переважаючими з них є засоби інтелектуальної обробки інформації, які є універсальними і ефективними апроксиматорами, легко настраюються (адаптуються) під змінювані влас-




Рис. 1. Структура Вінера–Гаммерштайна прогнозуючої моделі нелінійного динамічного ОК

тивості ОК і, відповідно, є ефективними засобами моделювання складних систем.

Рівняння ОК (1) на основі НМ прямого поширення з прихованим шаром [5] пропонується наводити у вигляді рівняння згортки:

$$\hat{Y}[k+n] = \sum_{\tau \in P} \Phi_{\hat{Y}} \left\{ \sum_{l \in Q} v_l[\tau] \Phi_l \left( \sum_{m \in Q} v_{l,m}[\tau] y_m[k-\tau] \right) \right\}, \quad (13)$$

де  $P$  – множина глибини пам'яті відповідних входів;  $\Phi_{\hat{Y}}$  – активаційна функція вихідного шару НМ;  $Q$  – множина входів нейронів;  $l$  – порядковий номер входу вихідного шару НМ;  $v_l$  – вагові коефіцієнти вихідного шару;  $\Phi_l$  – активаційна функція нейронів прихованого шару;  $m$  – порядковий номер входу НМ;  $v_{l,m}$  – вагові коефіцієнти зв'язку  $m$ -го входу і  $l$ -го нейрона;  $y_m$  – вхід НМ.

У загальному випадку входами НМ (13) згідно з (1), (2) і рис. 1 є  $\{\hat{Y}[k], \hat{Z}[k]\} \subset \{y_m[k-\tau]\}$ , а її структурними характеристиками –  $\{T_s, P, \Phi_{\hat{Y}}, \Phi_l, r_s\} \subset \Phi$ , де  $T_s$  – тип структури і  $r_s$  – розмір прихованого шару:  $r_s \subset Q$ . При цьому параметрами НМ є  $\{v_l, v_{l,m}\} \subset a$ .

Прогнозування за допомогою НМ з радіальними базисними функціями (РБФ) [5] виконується згідно з рівнянням

$$\hat{Y}[k+n] = \sum_{\tau \in P} \Phi_{\hat{Y}} \left\{ \sum_{l,m \in Q} v_l \Phi_l(\vartheta_l, \|y_m[k-\tau] - v_l\|) \right\}, \quad (14)$$

де  $\vartheta_l, v_l$  – параметри РБФ  $l$ -го нейрона прихованого шару.

Структурними характеристиками НМ (14) є  $\{T_s, P, \Phi_{\hat{Y}}, \Phi_l, r_s\} \subset \Phi$ , а її параметрами –  $\{v_l, \vartheta_l, v_l\} \subset a$ .

Рівняння ОК на основі гібридної НМ із нечіткою логікою [5] пропонується наводити у вигляді

$$\hat{Y}[k+n] = \sum_{\tau \in P} \sum_{m \in Q} \beta_m[\tau] \alpha_m[k-\tau], \quad (15)$$

де  $\beta_m[\tau] = U_m^{-1}(\alpha_m[\tau] / \sum_m \alpha_m[\tau])$ ;  $\alpha_m[k-\tau] = \text{Tn} \{L_{l,m}(y_m[k-\tau])\}$ ;  $U = U(a_U)$ ;  $L = L(a_L)$ .

Тут  $U_m^{-1}$  – функція, зворотна функції належності проміжного виходу  $m$  мережі з параметрами  $a_U$ ;  $\alpha_m$  – значення проміжного виходу;  $\text{Tn}$  – довільна  $t$ -норма [5] моделювання логічної операції “І”;  $L_{l,m}$  – функція належності нечіткого правила  $l$  входу  $m$  з параметрами  $a_L$ .

Структурними характеристиками НМ (15) є  $\{T_s, P, U_m, L_{l,m}, r_p\} \subset \Phi$ , де  $r_p$  – кількість правил розкладання по входах:  $r_p \subset Q$ , а її параметрами –  $\{a_U, a_L\} \subset a$ .

Ідентифікація параметрів (навчання) НМ прямого поширення (13) здійснюється, зазвичай, за допомогою градієнтних алгоритмів, наприклад алгоритму зворотного поширення похибки [5] в просторі параметрів  $\{v_l, v_{l,m}\} \subset a$  при вибраних структурі моделі ОК і структурних характеристиках  $\Phi$  з метою мінімізації похибки прогнозу (3) чи (9). При навчанні НМ із РБФ (14) спочатку визначаються центри і відхилення для радіальних елементів, після чого оптимізуються параметри лінійного вихідного шару:  $\{v_l, \vartheta_l, v_l\} \subset a$ . Навчання гібридної НМ (15) виконується аналогічно НМ (13) оптимізацією параметрів функцій належності

$\{a_U, a_L\} \subset a$ . Перевагою цих алгоритмів параметричного навчання НМ є простота і швидкодія, а недоліком — локальність (висока ймовірність застрягання в локальному екстремумі).

### Методика ідентифікації

Відповідно до викладеного вище задача (4), (5) має велику розмірність (кількість структурних характеристик і параметрів у дійсності становить сотні, тисячі й десятки тисяч). Внаслідок цього самостійне використання пошукових алгоритмів глобальної оптимізації для структурно-параметричної ідентифікації має низьку ефективність (малу швидкість збіжності) через їх відносно низьку швидкодію. Тому доцільним є спільне використання (композиція) алгоритмів глобальної оптимізації (для структурної ідентифікації моделі) і алгоритмів локальної оптимізації (для параметричного навчання та ідентифікації моделі).

Таким чином, структурно-параметрична ідентифікація нелінійних динамічних ОК складається з таких етапів.

#### 1. Визначення стану ОК (1):

- знаходження режиму функціонування ОК і його розмірностей  $d_i$  і  $d_{\bar{y}}$  (див. рис. 1) [13];

- формування вектора оцінки спостереження (прогнозу)  $\hat{Z}[k]$  (2).

#### 2. Формулювання задачі структурно-параметричної ідентифікації з визначенням (вибором):

- методу структурної (глобальної) оптимізації (ПВП чи ГА згідно з (7), (8));
- критерію структурної оптимізації (10)–(12);
- способів врахування обмежень;
- типу структури моделі (наприклад, Вінера–Гаммерштайна на рис. 1);
- базисних функцій із виділенням їх структурних характеристик і параметрів згідно з (13)–(15);

- методів параметричної оптимізації з вибором критерію регуляризації (3) або (9).

Цей вибір виконується на етапі проектування системи керування ОК і базується на апріорних даних.

#### 3. Визначення оптимальної структури і параметрів моделі ОК (1):

- ідентифікація структури за допомогою композиції методів глобальної оптимізації (7)

або (8), що містять у собі генерування структур моделей-претендентів (базисних функцій (13)–(15) із своїми структурними характеристиками), і методів локальної параметричної оптимізації (навчання НМ-моделей (13)–(15)), а також селекцію кращих моделей за критерієм структурної оптимізації (10), (11) або (12);

- ідентифікація параметрів моделі оптимальної структури за допомогою навчання методом локальної параметричної оптимізації за критерієм регулярності (3) або (9) на всій вибірці даних.

Для скорочення термінів навчання моделей на реальному ОК доцільно на етапі проектування системи керування ОК виконувати переднавчання цієї моделі на наявних експериментальних даних і (або) адекватних моделях ОК. При цьому адаптивна ідентифікація моделі в процесі функціонування ОК дає можливість істотно знизити витрати на попередні експериментальні дослідження його режимів роботи.

### Моделювання

Як приклад виконаємо за допомогою розроблених програм у середовищі MatLab ідентифікацію прогнозуючих моделей процесу крупнокускового дроблення (ККД) за експериментальними даними [14], а також ідентифікацію процесу мокрого самоздрібнення (МСЗ), що як ОК по каналу “подача руди–вихід готового класу” описується послідовно з’єднаними аперіодичною ланкою із запізненням та безінерційною квадратичною ланкою (ПІТ2) [15]. З особливостей цих процесів глибина прогнозу прийнята  $n = 3$  такти, а глибина пам’яті по різних входах від 1 до 4. Похибки виміру для процесу ККД не перевищували 10 %, а розмір реалізації становив  $N = 58$ . Для моделювання процесу МСЗ (моделі ПІТ2) як вхідного сигналу використовувався смуговий кореляційний нормований сигнал із гауссівським шумом амплітудою 10 % від рівня сигналу, а розмір реалізації становив  $N = 1024$ .

Як критерій структурної оптимізації було вибрано комбінований критерій (12), оскільки він проявив малу чутливість до варіації шуму і глибини прогнозу (малий зсув глобального мінімуму в просторі ознак).

При ідентифікації процесів ККД і МСЗ використовувалася структура моделей Вінера–Гаммерштайна з базисними функціями НМ (13)–(15), як глобальні методи оптимізації застосовувалися алгоритм ПВП із прискорюва-

чем кроку пошуку і ГА з однотоочечним схрещуванням, селективним вибором батьків із витисненням. Загалом ці алгоритми за точністю дали подібні результати. При цьому ГА виявив вищу швидкість збіжності (ГА виходить в область оптимальних рішень на перших поколіннях, а ПВП – після 15 ітерацій), а алгоритм ПВП – вищу швидкодію (до 6 с на ітерацію в ПВП і 9,5 с на покоління в ГА) при обчисленнях на процесорі Pentium IV. Загалом час пошуку оптимальних рішень становив 5–8 хв, що значно менше періодичності зміни режимів функціонування процесів рудопідготовки, які мають терміни від кількох годин.

В результаті моделювання встановлено, що мінімуму критерію (12) відповідають каскадні НМ-моделі прямого поширення (13) з логістичною функцією активації прихованого

шару і лінійною функцією у вихідному шарі. При цьому кількість нейронів у прихованому шарі для моделі процесу ККД дорівнює 23 нейронам, а для моделі процесу МСЗ – 47.

Час обчислень по цих моделях становить менше 1 мс на цикл прогнозу, що не вносить часових обмежень на їх застосування в контурах керування (еквівалентні сталі часу процесів ККД і МСЗ мають діапазон від десятків до сотень секунд).

Результати параметричної оптимізації НМ-моделей прямого поширення оптимальної складності процесів ККД і МСЗ (ПІТ2) наведено на рис. 2, а і б.

Як міра точності ідентифікованих моделей використовувався критерій мінімуму відносної похибки покрокового інтегрування (9), значення якого дорівнювали: для моделі ККД – 0,0365 і для моделі МСЗ (ПІТ2) – 0,0348, що набагато краще, ніж похибка ідентифікації за МГУА (0,0653 [14]). При цьому статистична перевірка показала значущість такого зниження похибки, а отримані прогнозуючі моделі з ідентифікованими структурами і параметрами з ймовірністю 0,99 адекватні динаміці розглянутих процесів.

## Висновки

На основі композиції методів глобальної і локальної оптимізації розроблено методику структурно-параметричної ідентифікації нелінійних динамічних ОК у класі прогнозуючих чітких і нечітких нейромережових моделей, які легко адаптуються під змінювані режими функціонування ОК.

Моделюванням встановлено, що отримані запропонованою методикою моделі процесів дроблення і здрібнювання мають підвищену точність, а це сприяє підвищенню ефективності керування даними процесами. При цьому часові витрати на реалізацію методики і обчислення моделей не накладають обмежень на їх застосування в автоматизованих системах керування технологічними процесами рудопідготовки.

Подальші дослідження спрямовуватимуться на розробку алгоритмів оптимального керування нелінійними динамічними ОК з їх структурно-параметричною ідентифікацією в процесі функціонування системи керування.




Рис. 2. Результати ідентифікації процесів ККД (а) і МСЗ (б): — — реальний процес; — · — прогнозований процес

Г.В. Кузнецов, В.И. Корниенко, А.В. Герасина

КОМПОЗИЦИОННАЯ СТРУКТУРНО-ПАРАМЕТРИЧЕСКАЯ ИДЕНТИФИКАЦИЯ НЕЛИНЕЙНЫХ ДИНАМИЧЕСКИХ ОБЪЕКТОВ УПРАВЛЕНИЯ

Разработана методика структурно-параметрической идентификации нелинейных динамических объектов управления в классе прогнозирующих нейросетевых моделей на базе композиции методов глобальной и локальной оптимизации. Оценена эффективность ее использования на примере идентификации технологических процессов рудоподготовки.

G.V. Kuznetsov, V.I. Korniyenko, O.V. Gerasina

COMPOSITION STRUCTURAL-PARAMETRIC IDENTIFICATION OF NONLINEAR DYNAMIC CONTROLLED OBJECTS

By combining the methods of global and local optimization, we devise the method of structural-parametric identification of nonlinear dynamic controlled objects in the class of predicted neural network models. We estimate its application efficiency by the example of identification of manufacturing processes of ore-preparation.

1. *Ивахненко А.Г.* Долгосрочное прогнозирование и управление сложными системами. — К.: Техніка, 1975. — 312 с.
2. *Mueller J.-A., Lemke F.* Self-Organising Data Mining. An Intelligent Approach To Extract Knowledge From Data. — Berlin: Verlag, 1999. — 225 p.
3. *Справочник по теории автоматического управления /* Под ред. А.А. Красовского. — М.: Наука, 1987. — 712 с.
4. *Корниенко В.И., Пивоварова А.В.* Интеллектуальные методы структурно-параметрической идентификации технологических процессов рудоподготовки // *Гірничча електромеханіка та автоматика: Наук.-техн. зб.* — 2008. — Вип. 80. — С. 71–77.
5. *Круглов В.В., Дли М.И., Голунов Р.Ю.* Нечеткая логика и искусственные нейронные сети. — М.: Солон, 1996. — 348 с.
6. *Бодянский Е.В., Слипенченко А.Н.* Ансамбль нейропредикторов с переменным числом узлов // *Радіоелектроніка. Інформатика. Управління.* — 2004. — № 2. — С. 107–112.
7. *Тененев В.А., Паклин Н.Б.* Гибридный генетический алгоритм с дополнительным обучением лидера // *Интеллектуальные системы в производстве.* — Ижевск: Изд-во ИжГТУ, 2003. — № 2. — С. 181–206.
8. *Растригин Л.А.* Адаптация сложных систем. — Рига: Зинатне, 1981. — 376 с.
9. *Holland J.H.* Adaptation in natural and artificial systems. An introductory analysis with application to biology, control and artificial intelligence. — London: Bradford b.ed., 1994. — 211 p.
10. *Степаншко В.С.* Анализ эффективности критериев структурной идентификации прогнозирующих моделей // *Пробл. управления и информатики.* — 1994. — № 3-4. — С. 13–21.
11. *Nelles O.* Nonlinear System Identification: From Classical Approaches to Neural and Fuzzy Models. — Berlin: Springer, 2001. — 785 p.
12. *Ljung L.* Identification of Nonlinear Systems // *Proceeding of the IEEE.* — 2006. — N 6. — P. 1–10.
13. *Корнієнко В.І., Скриль Д.Ю.* Ідентифікація нелінійних процесів по часових реалізаціях // *Наук. вісник Нац. гірнич. ун-ту.* — 2009. — № 3. — С. 85–89.
14. *Качан Ю.Г., Корниенко В.И.* Результаты идентификации процесса дробления по принципу самоорганизации // *Горная электромеханика и автоматика: Респ. межвед. науч.-техн. сб.* — 1988. — Вып. 53. — С. 32–38.
15. *Марюта А.Н., Качан Ю.Г., Бунько В.А.* Автоматическое управление технологическими процессами обогащения фабрик. — М.: Недра, 1983. — 278 с.

Рекомендована Радою  
факультету прикладної математики  
НТУУ “КПІ”

Надійшла до редакції  
23 квітня 2009 року